Advanced Quantitative Analysis for Personalized Medicine

Machine Learning for Psychologists and Biologists

ד"ר נוריאל ש. מור

פסיכולוגיה קלינית (Ph.D.)
פסיכולוגיה יישומית (M.Sc.)
מדעי המחשב (M.Sc.)
מדעי הרפואה: פיזיולוגיה ופרמקולוגיה (M.Sc.)
חוג לאחר תואר במדעי המחשב (B.Sc.)
תעודת הוראה במתמטיקה (B.Ed.)
פסיכולוגיה וביולוגיה בהדגש מדעי המוח (B.Sc.)

nuriel.mor@gmail.com

0523572145

המודלים הסטטיסטיים הנלמדים במדעי החברה, מדעי ההתנהגות, מדעי החיים ורפואה, מאפשרים הסקה לגבי הבדל בין קבוצות ובחינה של היפותזות ספציפיות על סמך נתוני המחקר. אין ביכולת מודלים אלו לתת חיזוי לנתונים חדשים שלא הוצגו במחקר. הלכה למעשה, בפרקטיקה יש צורך לבצע החלטות קליניות ברמת האינדיבידואל עם נתונים חדשים, שלא הוצגו במחקר. מודלים סטטיסטים מסורתיים אלו מהווים מכשול חישובי לתת חיזוי ברמת האינדיבידואל.

בקורס זה נלמד על גישה חישובית אחרת (למידת מכונה ולמידה עמוקה), הנמצאת בשימוש הולך וגובר, ברפואה מותאמת אישית. גישה זו מאפשרת לבצע מחקרים בתחומי מדעי החברה, מדעי ההתנהגות, מדעי החיים ורפואה, ולבנות מודלים שיאפשרו חיזוי, פרקטי עם משמעות קלינית מעשית, עבור אינדיבידואל עם נתונים חדשים שלא הוצגו במחקר עצמו.

The traditional methods of analysis based on general linear modeling (GLM) are restricted to testing specific hypotheses without an ability to generalize and give predictions for data that was not under study (Orrù et al., 2012). GLM allows inferring only at the group level of how much variance in the dependent variable can be explained by the independent variables and calculating the probability of rejecting a null hypothesis (Galatzer-Levy et al., 2014; Orrù et al., 2012).

These traditional statistical methods of analysis do not allow inference about individuals' previously unseen data. GLM is restricted to testing specific hypotheses based on the data under study, without generalization beyond this seen data (Galatzer-Levy et al., 2014; Orrù et al., 2012).

In practice, however, there is a need to make clinical decisions about individuals (Orrù et al., 2012).

Computational models used in psychological and biological research, however, are barriers to making such predictions at the individual level.

Inferences at the level of the individual require analytical methods that are designed for this purpose.

In this course we learn about a different approach named Machine Learning (ML) which allow inferring at the level of the individual, and allow categorization of an individual's previously unseen data, therefore yielding results with practical, clinical application (Orrù et al., 2012). **The use of a ML approach to predict an outcome is increasingly used in developing individualized medicine and is known as forecasting** (Galatzer-Levy et al., 2014).

Content

Subject	Bibliography (initial)
1. Machine learning & Supervised learning (overview)	Bishop, C. M. (2006). *Pattern recognition and machine learning.* New York: springer. Ian Goodfellow and Yoshua Bengio & Aaron Courville (2016). *Deep Learning*. MIT Press. http://www.deeplearningbook.org נוריאל ש. מור (2017) למידה עמוקה לבינה מלאכותית
2. Logistic regression	Bishop, C. M. (2006). *Pattern recognition and machine learning*. New York: springer. Machine Learning by Stanford University (Andrew Ng) on Coursera.
3.. Neural networks for machine learning	Bishop, C. M. (2006). *Pattern recognition and machine learning*. New York: springer. Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv*:1207.0580. Ian Goodfellow and Yoshua Bengio & Aaron Courville (2016). *Deep Learning*. MIT Press. http://www.deeplearningbook.org Machine Learning by Stanford University (Andrew Ng) on Coursera. Neural Networks for Machine Learning by University of Toronto (Geoffrey Hinton) on Coursera. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958. Zhang, S., Bao, Y., Zhou, P., Jiang, H., & Dai, L. (2014). Improving deep neural networks for LVCSR using dropout and shrinking structure. *In Acoustics, Speech and Signal Processing (ICASSP), 2014 IEEE International Conference on (pp. 6849-6853). IEEE.* נוריאל ש. מור (2017) למידה עמוקה לבינה מלאכותית
4. Forward and backward propagations	Bishop, C. M. (2006). *Pattern recognition and machine learning*. New York: springer. Machine Learning by Stanford University (Andrew Ng) on Coursera. Neural Networks and Deep Learning by deeplearning.ai Ian Goodfellow and Yoshua Bengio & Aaron Courville (2016). *Deep Learning*. MIT Press. http://www.deeplearningbook.org נוריאל ש. מור (2017) למידה עמוקה לבינה מלאכותית

5. Support vector machines	Bishop, C. M. (2006). *Pattern recognition and machine learning*. New York: springer. Machine Learning by Stanford University (Andrew Ng) on Coursera. Orru, G., Pettersson-Yeo, W., Marquand, A. F., Sartori, G., and Mechelli, A. (2012). Using support vector machine to identify imaging biomarkers of neurological and psychiatric disease: a critical review. *Neuroscience and Biobehavioral Reviews, 36(4)*, 1140-1152
6. Deep neural networks	Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv*:1207.0580. Ian Goodfellow and Yoshua Bengio & Aaron Courville (2016). *Deep Learning*. MIT Press. http://www.deeplearningbook.org Neural Networks and Deep Learning by deeplearning.ai Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958. Zhang, S., Bao, Y., Zhou, P., Jiang, H., & Dai, L. (2014). Improving deep neural networks for LVCSR using dropout and shrinking structure. *In Acoustics, Speech and Signal Processing (ICASSP), 2014 IEEE International Conference on* (pp. 6849-6853). נוריאל ש. מור (2017) למידה עמוקה לבינה מלאכותית
7. Machine learning in psychological, medical and biological research	Galatzer-Levy, I. R., Karstoft, K. I., Statnikov, A., & Shalev, A. Y. (2014). Quantitative forecasting of PTSD from early trauma responses: A machine learning application. *Journal of psychiatric research*, *59*, 68-76. Gong, Q., Li, L., Tognin, S., Wu, Q., Pettersson-Yeo, W., Lui, S.,and Mechelli, A. (2014). Using structural neuroanatomy to identify trauma survivors with and without post-traumatic stress disorder at the individual level. *Psychological medicine*, 44(1), 195-203. Karstoft, K. I., Statnikov, A., Andersen, S. B., Madsen, T., and Galatzer-Levy, I. R. (2015). Early identification of posttraumatic stress following military deployment: Application of machine learning methods to a prospective study of Danish soldiers. *Journal of affective disorders*, 184, 170-175. Orru, G., Pettersson-Yeo, W., Marquand, A. F., Sartori, G., and Mechelli, A. (2012). Using support vector machine to identify imaging biomarkers of neurological and psychiatric disease: a critical review. *Neuroscience and Biobehavioral Reviews, 36(4)*, 1140-1152 Rosellini, A. J., Dussaillant, F., Zubizarreta, J. R., Kessler, R. C., & Rose, S. (2018). Predicting posttraumatic stress disorder following a natural disaster. *Journal of psychiatric research*, 96, 15-22